

基于特征选择的 NGO-RF 热轧 H 型钢水平辊轧制力预测

臧德宇¹, 吴 龙², 林太阳¹, 潘建洲^{3,4}

(1. 福建农林大学 机电工程学院, 福建 福州 350002; 2. 三明学院 机电工程学院, 福建 三明 365004;
3. 北京科技大学 材料科学与工程学院, 北京 100083; 4. 福建三钢(集团)有限公司, 福建 三明 365000)

摘要: 为了得到较为精确的水平辊轧制力, 收集福建罗源闽光钢铁轧钢厂的实际轧制参数, 并进行相关参数计算与预处理, 构建包含多输入特征及多规格的 H 型钢水平辊轧制力数据集。为有效预测 H 型钢的水平辊轧制力, 首先, 运用孤立森林算法和树模型进行离群点检测与特征选择; 其次, 划分数据集并采用随机森林模型作为基础模型进行训练与验证; 再次, 应用北方苍鹰优化算法优化随机森林模型; 最后, 输入处理后的 H 型钢水平辊轧制力测试集数据, 输出轧制力预测值。将所建模型(NGO-RF)与未经优化的随机森林模型、支持向量机模型、多层感知神经网络模型、卷积神经网络模型, 以及经过北方苍鹰优化算法优化的支持向量机模型和多层感知神经网络模型对比, 结果显示, 所建模型在预测性能上优于上述所有模型, 具有较高的准确性与适用性。此外, 利用所建模型对 H 型钢 588 mm×300 mm×12 mm×20 mm 新规格产品的轧制力进行预测, 对比模型预测值与实测值, 平均误差仅为 6.05%, 进一步证实了所建模型能够较好地实现对 H 型钢水平辊轧制力的预测。

关键词: H 型钢; 水平辊轧制力; 随机森林; 北方苍鹰优化算法; 特征选择

DOI: 10.13330/j.issn.1000-3940.2025.01.016

中图分类号: TG335.4⁺2

文献标志码: A

文章编号: 1000-3940 (2025) 01-0122-12

Prediction on rolling force of horizontal roller of NGO-RF hot-rolled H-beams based on feature selection

Zang Deyu¹, Wu Long², Lin Taiyang¹, Pan Jianzhou^{3,4}

(1. School of Mechanical and Electronic Engineering, Fujian Agriculture and Forestry University, Fuzhou 350002, China;
2. School of Mechanical and Electronic Engineering, Sanming University, Sanming 365004, China;
3. School of Material Science and Engineering, University of Science and Technology Beijing, Beijing 100083, China;
4. Fujian Sansteel (Group) Co., Ltd., Sanming 365000, China)

Abstract: In order to obtain more accurate rolling force of horizontal roller, the actual rolling parameters of Fujian Luoyuan Minguang Iron and Steel Rolling Mill were collected, and the calculation and preprocessing of relevant parameter were performed to construct a rolling force dataset of horizontal roller for H-beam containing multi-input features and multiple specifications. To effectively predict the rolling force of horizontal roller for H-beam, firstly, the outlier detection and feature selection were conducted by isolation forest algorithm and tree model, and the dataset was divided, using random forest model as the base model for training and validation. Next, the random forest model was optimized by northern goshawk optimization algorithm. Furthermore, the processed test set data of rolling force for H-beam horizontal roller was inputted, and the predicted rolling force values were output. In addition, the constructed model (NGO-RF) was compared with the unoptimized random forest model, support vector machine model, multi-layer perceptron model, convolutional neural network model, as well as support vector machine model and multi-layer perceptron neural network model optimized by northern goshawk optimization algorithm. The results show that the constructed model outperforms all models mentioned above in terms of performance prediction, and it has high accuracy and adaptation. Additionally, the rolling force of new H-beam 588 mm×300 mm×12 mm×20 mm specification products are predicted by using the constructed model. Comparing the predicted values of the model with the actual measured values, the average error is only 6.05%, further confirming that the constructed model can effectively predict the rolling force of H-beams horizontal roller.

Key words: H-beam; rolling force of horizontal roller; random forest; northern goshawk optimization algorithm; feature selection

H 型钢是建筑和工程领域中的一种主要材料,

因其横截面为“H”形状而得名。与其他建筑材料相比, H 型钢具有更优的截面面积分配和更合理的强度与重量比, 结构中的各个部分均以直角排列, 这赋予了其在多个方向上的卓越抗弯性能。此外, H 型钢还具备施工简便、成本节约和结构轻量化等优势, 被视为典型的环保型钢材。在 H 型钢的生产过程中, 轧制力的预测精度对于控制 H 型钢腹板和

收稿日期: 2024-10-11; 修订日期: 2025-01-01

基金项目: 福建省科技厅“揭榜挂帅”成果转化项目 (2023T5001); 福建省科技重大专项 (2022HZ026025)

作者简介: 臧德宇 (1999-), 男, 硕士研究生

E-mail: zangdeyu2022@fafu.edu.cn

通信作者: 吴 龙 (1973-), 男, 博士, 教授

E-mail: smuwl@126.com

翼缘的厚度及形状至关重要,直接关系到成品的尺寸精度和表面质量^[1]。轧制力的有效预测不仅能指导实际的轧制操作,还能为轧件在加热炉内的加热时间、轧制节奏的调整以及轧机负载情况的评估提供重要参考^[2-4]。

相关领域的学者对此进行了大量研究,贺庆强等^[5]通过编写 Python 代码程序实现单元重构,在 ABAQUS 环境中构建适合多道次型钢轧制过程的有限元综合仿真模型,利用所建模型对 H 型钢多道次粗轧进行实验研究,建立了经验公式;张海龙等^[6]通过实验手段获取 Q235 钢在高温下的应力-应变曲线,采用多元回归的方法,建立 H 型钢连轧过程中万能轧机的轧制力数学模型,并给出了 3 种规格 H 型钢连轧轧制力模型的回归系数,所建模型可以提高预测精度。赵景云等^[7]基于分离腹板和翼缘相互影响的思路建立了两种 H 型钢万能轧制模型,通过研究不同延伸比和面积比条件下水平辊与立辊的轧制力与平板轧制的关系,总结归纳出 H 型钢万能轧制力公式,并与有限元模型计算结果以及实测值进行对比,发现其具有较高的相似度;张向军等^[8]提出一套简便有效的轧制力能分析方法,其结果可以满足 H 型钢矩形坯热轧开坯的轧制力能校核需要,可以为生产实践的工艺调整提供参考。但是以上方法大多是针对理论模型进行改进,在建模过程中,这些模型通常采用西姆斯公式来计算参数,并简化了许多实际因素。虽然这些传统模型计算出的理论值可以为实际提供一定指导,但是一旦换一个新规格材料,仍需要再次进行大量计算,且不能保证预测精度。

随着智能算法与大数据技术的发展,国内外学者针对轧制力模型做了大量研究。Zhang X D 等^[9]提出了一种改进的贝叶斯正则化神经网络模型,通过在目标函数中引入表征网络复杂度的有界项来构造改进的贝叶斯神经网络,实现了比传统轧制力模型更加精准的预测。窦博^[10]利用贝叶斯神经网络预测精轧轧制力,选取化学元素含量及多个参数作为输入,轧制力作为输出,并利用乘法网络优化轧制力预测模型,大幅提高了轧制力预测精度。Zheng G 等^[11]通过改进粒子群优化算法,优化 BP 神经网络,实现了可逆式冷轧轧制力的高精度预测。魏立新等^[12]通过在遗传算法中加入精英策略、自适应遗传算子与精英个体保留策略,完成对 SVM 模型参数的寻优,提高了轧制力预测精度。马威等^[13]利用深度学习框架 TensorFlow,构建了一种深度前馈神经网络轧制力模型,针对热连轧精轧机组的大量轧制

数据进行建模实验,实现轧制力的高精度预测。Wang W Y 等^[14]提出了一种基于 K 近邻 (K-Nearest Neighbor, KNN) 算法的轧制力预测模型,算法训练时长与精度均优于线性回归模型。冀秀梅等^[15]提出一种基于极限学习机的综合神经网络,并利用化学成分计算基准变形抗力,将其作为模型输入,提高了轧制力的预测精度。章顺虎等^[16]对工业大数据进行归一化处理,系统优化了神经网络模型,利用误差间距补偿方法实现了网络模型与理论模型的融合,所建模型的预测结果可以与实测值较好地吻合。丁敬国等^[17]构建了基于鲸鱼算法优化极限学习机协同长短时记忆网络 (Whale Algorithm to Optimize Extreme Learning Machine Cooperative Long-Term and Short-Term Memory Network, WOA-ELM-LSTM) 的热轧轧制力预测模型,解决了热轧过程中非稳态环境下轧制力设定精度低的难题,实现了对热轧轧制力的实时高精度预测。

通过上述研究可以看出,近年来,国内外专家学者在轧制力的建模上取得了很大进展,但上述模型主要集中在板带轧制领域。近十年来,几乎没有学者采用机器学习或神经网络等方法进行 H 型钢的轧制力预测的研究。由于 H 型钢的规格相对较少,可用于分析的数据量有限,上述模型对于训练数据的质量要求较高,算法存在训练速度较慢、过拟合等问题,且在面对 H 型钢热连轧生产中的温度变化、轧机振动等复杂影响因素时,模型预测精度不足,仍无法满足企业对轧制力预测精度的需求。

H 型钢由腹板与翼缘构成,在 H 型钢热轧生产中,轧制力的波动显著,受多种因素影响,由于水平辊为主动辊,立辊为从动辊,所以厂内更注重水平辊轧制力的精准控制与预测。为了实现 H 型钢水平辊轧制力的有效预测,本文通过收集生产现场多个规格的 H 型钢尺寸参数以及轧机参数等相关数据,利用 Python 编程处理数据,构建了一个综合数据集,利用孤立森林算法 (Isolation Forest) 实现数据离群点检测,利用树模型 (Tree Model) 实现模型输入特征选择,利用随机森林 (Random Forest, RF) 作为基础模型处理数据集,利用北方苍鹰优化算法 (Northern Goshawk Optimization, NGO) 对随机森林模型进行参数寻优。将本文所建模型与 RF、支持向量机 (Support Vector Machine, SVM)、多层感知神经网络 (Multilayer Perceptron, MLP)、卷积神经网络 (Convolutional Neural Network, CNN)、NGO-SVM、NGO-MLP 模型进行比较,发现本研究所提出的 NGO-RF

模型在数据量有限的情况下仍展现了更优越的预测性能,验证了该模型的有效性和准确性。

1 数据集构建

本文所使用的三架串联可逆轧机是从西马克集

团引进的, H 型钢生产方式采用 X-H 型轧制, 利用两架万能轧机 (UR、UF) 与一架轧边机 (E) 进行往复式轧制, 其中, 腹板与翼缘的压下量分别由一对水平辊与一对立辊进行控制, 水平辊为主动辊, 立辊为从动辊, 三机架连轧轧机及孔型示意图如图 1 所示。

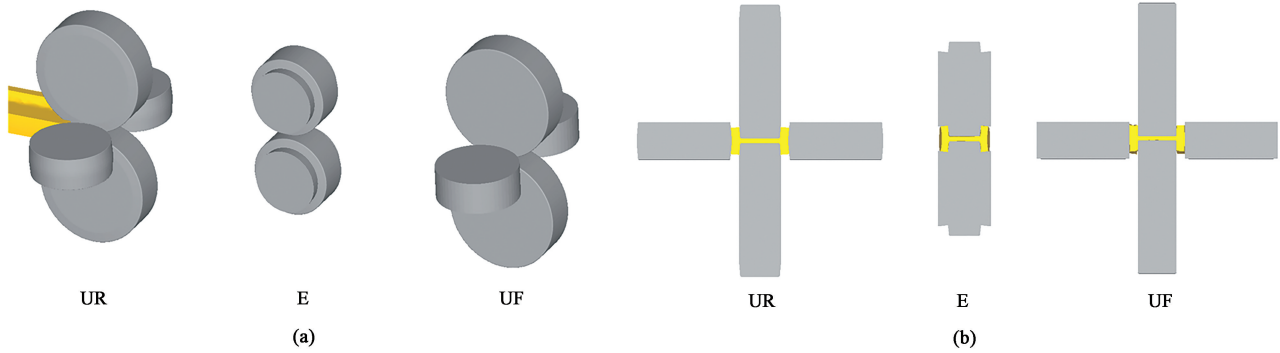


图 1 三架串联可逆轧机 (a) 及孔型示意图 (b)

Fig. 1 Schematic diagrams of three-stand tandem reversing mill (a) and hole type (b)

在轧制现场, 轧辊由液压缸控制, 液压缸作用于轧辊主轴, 通过控制液压缸的压入量与挤入量来调整轧机辊缝的大小。控制水平辊的上下 4 个液压缸呈对称布置, 以控制 H 型钢腹板的压入量; 左右两侧的液压缸控制立辊的挤入量, 即翼缘的压入量; 左下方的液压缸用于防止上下水平辊的中心线在竖直方向上出现偏差。图 2 展示了万能轧机上液压缸与压力传感器布置示意图, 其中 DS 表示传动侧, OS 表示操作侧, 图 2 中数字表示液压缸的控制行程范围, 如 0~160, 单位 mm。液压缸内安装的压力传感器可以实时采集轧制力数据, 上水平辊的两个压力传感器数据之和为上水平辊轧制力, 下水平辊轧制力同理。将采集到的上下水平辊轧制力数据取平均值作为水平辊轧制力的实测值。

通过采集厂内最近半年内轧制的大、中、小共 20 个规格 H 型钢的初始数据: 轧件初始、轧后腹板与翼缘厚度、轧辊辊径等参数, 并利用 Python 编程计算出多个参数。由于厂内采用可逆式往复轧制, 每条钢需要轧制奇数个道次, 厂内以 5 道次与 7 道次居多, 每个轧件分别通过 UR 与 UF 时分别记作一个 PASS, 连续通过一个 UR 与一个 UF 记为一个道次。本文所采集的数据共计 319 个 PASS, 每个 PASS 对应一条样本与一条实测轧制力值, 部分参数的计算公式如下:

$$v = \frac{2v\sqrt{\Delta h/R'}}{h_0 + h_1} \quad (1)$$

$$\lambda = \frac{\ln(h_0/h_1)}{\ln(ss_0/ss_1)} \quad (2)$$

$$\Delta T = \zeta \cdot 12.9 \cdot \frac{Z}{ss_0} \cdot \left(\frac{T}{1000}\right)^4 \quad (3)$$

$$\zeta = 1 - \frac{1}{90} \cdot \arctan \frac{b_1 \cdot \cos \beta_1}{k_a + b_1 \cdot \sin \beta_1} \quad (4)$$

$$b_1^2 - b_0^2 = 8mL_v(h_0 - h_1) - 4m(h_0 + h_1)L_v \ln \frac{b_1}{b_0} \quad (5)$$

$$L_h = \sqrt{R_h \Delta ss} \quad (6)$$

$$L_v = \sqrt{R_v \Delta h} \quad (7)$$

式中: v 为轧制时平均变形速度, s^{-1} ; v 为轧辊圆周速度, $(m \cdot s^{-1})$; Δh 为翼缘压下量, mm; R' 为轧辊半径; h_0 为轧件初始翼缘厚度, mm; h_1 为轧件轧后翼缘厚度, mm; λ 为腿腰延伸比; ss_0 为初始腹板厚度, mm; ss_1 为轧后腹板厚度, mm; ΔT 为轧件轧制前后温度差, $^{\circ}C$; ζ 为辐射角系数; Z 为放热时间, s, 其为纯轧时间与间隙时间之和; T 为轧件温度, $^{\circ}C$; b_1 为轧后翼缘宽度, mm; b_0 为轧件初始翼缘宽度, mm; k_a 为腹板内宽, mm; β_1 为立辊锥角, $(^{\circ})$; m 为外摩擦影响系数; L_h 与 L_v 分别为腹板与翼缘的接触弧长, mm; R_v 与 R_h 分别为立辊与水平辊的轧辊半径, mm; Δss 为腹板压下量, mm。

式中: $s(x, \beta)$ 为数据点 x 的异常分数, 范围为 $[0, 1]$; β 为训练数据样本量; $E[h(x)]$ 为 x 在多棵树中的路径长度的期望值, 也被称为平均路径长度; $h(x)$ 为路径长度; $c(\beta)$ 为一个包含 β 个样本的数据集, 树的平均值路径长度, 用来标准化记录 x 的路径长度; H 为调和数; ξ 为欧拉常数, 约为 $0.5772156649^{[19]}$ 。

异常值筛选的准则如下: 当 $E[h(x)]$ 约等于 $c(\beta)$, 则 $s(x, \beta) = 0.5$, 如果所有的结果均在 0.5 左右, 那么整个样本就无任何异常; 当 $E[h(x)]$ 越接近 0 , 则 $s(x, \beta)$ 越接近 1 , 观测的得分接近 1 时, 路径长度非常小, 那么数据点很容易被孤立, 就可以筛选出一个异常; 当 $E[h(x)]$ 越接近 $\beta-1$, 则 $s(x, \beta)$ 越接近 0 , 得分小于 0.5 , 路径长度就会变大, 然后就得到了一个正常的点。

由于生产现场存在 H 型钢放开空过的操作, 会降低腹板波浪缺陷的发生率, 也会使 H 型钢通过该轧机轧后腹板厚度变大, 导致压下量出现负值, 影响后面的结果, 本文数据中存在 3 条上述情况数据, 将这 3 条数据人为删除。鉴于输入特征的多样性以及同规格 H 型钢轧制参数的连续性, 采用孤立森林算法识别剩余数据中的异常点, 能够增强模型在预测轧制力方面的性能, 利用孤立森林异常值检测去除 8% 的异常值, 其可视化结果如图 3 所示。通过人为删除与孤立森林去除后的样本数据, 由原来的 319 条变为 292 条。

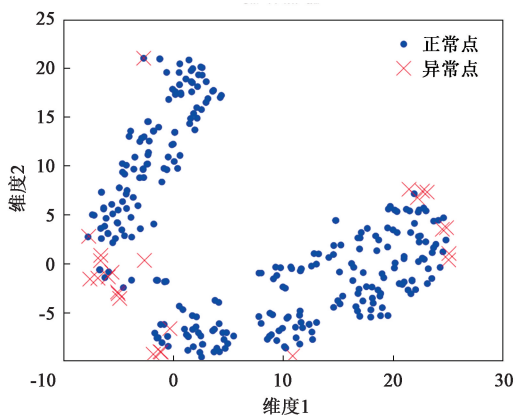


图 3 孤立森林离群点检测可视化

Fig. 3 Visualization of outlier detection using isolation forest

2.2 树模型特征选择

在传统的轧制力预测模型中, 板带轧制的参数, 如轧辊半径、轧制前后的轧件高度、轧件温度和轧制速度等, 常被作为模型的输入特征。然而, 对于 H 型钢轧制, 其横截面的温度变化、压下量等参数

与板带轧制的参数有本质的不同, 且影响 H 型钢轧制力的参数更为复杂多变, 因此, 不能简单地采用与板带轧制相同的输入参数来预测 H 型钢的轧制力。本研究通过分析 H 型钢与轧辊的初始数据, 计算轧制温度、速度、变形程度以及轧制时间等参数, 将其与初始轧件尺寸、轧辊半径等共 21 个独立变量作为模型输入特征, 并采用树模型进行特征选择, 以简化模型。

为了优化模型的预测能力, 选择随机森林算法作为基础模型, 将前文所述数据集输入至模型, 利用树模型分别选择 11、12、13、14、15、16、17、18 以及 19 个特征进行训练与预测。对比不同特征选择的模型性能, 对比结果如图 4 所示, 图 4a 为训练集模型性能对比, 图 4b 为测试集模型性能对比, R^2 为拟合决定系数, R^2 越接近 1 越好; MAE 为平均绝对误差, MAE 越小越好, 即图 4 中左上角位置的预测性能最佳。通过对比可知, 当选择 13 个特征进行模型训练时, 模型性能评价指标最优。通过上述步骤, 确保了特征选择的科学性和模型预测的准确性, 可以为 H 型钢轧制力的精确预测提供理论基础, 模型待选特征重要性如图 5 所示。

3 基于特征选择的 NGO-RF 模型

3.1 随机森林 BF

随机森林是一种集成学习 (Ensemble Learning) 方法, 由 Breiman L^[20] 在 2001 年提出, 适用于各种分类和回归问题, 特别是对于复杂的、高维度的数据集, 以及需要处理大量特征的问题。其通过结合多个决策树的预测结果来提高整体模型的预测准确性和泛化能力。该算法的核心在于利用装袋 (Bagging) 技术随机生成多个数据子集, 并对每个子集训练一个基决策树, 最终形成一个决策树的“森林”。在决策树的构建过程中, 随机森林引入了随机属性选择, 即在每个决策节点, 算法会从一个随机选定的属性子集中选择最优属性进行分裂, 这一策略不仅增加了模型的多样性, 也降低了过拟合的风险。

在回归问题中, 随机森林通常采用最小均方差 MSE 作为节点分裂的准则, 以最小化每个节点的样本集的 MSE 或两个子样本集的 MSE 之和:

$$\min_{a, s} \left\{ \min_{c_1, c_2} \left[\sum_{x_i \in D_1(a, s)} (y_i - c_1)^2 + \sum_{x_i \in D_2(a, s)} (y_i - c_2)^2 \right] \right\} \quad (11)$$

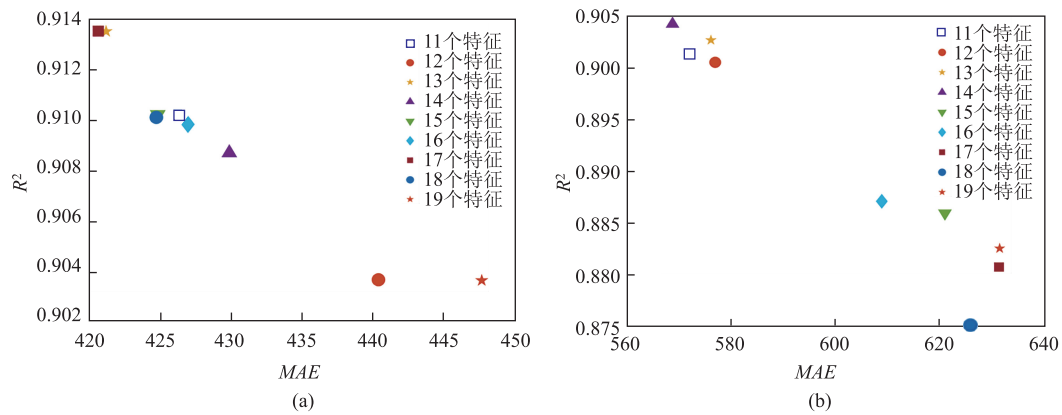


图 4 不同特征选择的模型性能评价

(a) 训练集 (b) 测试集

Fig. 4 Performance evaluation of models with different feature selections

(a) Training set (b) Test set

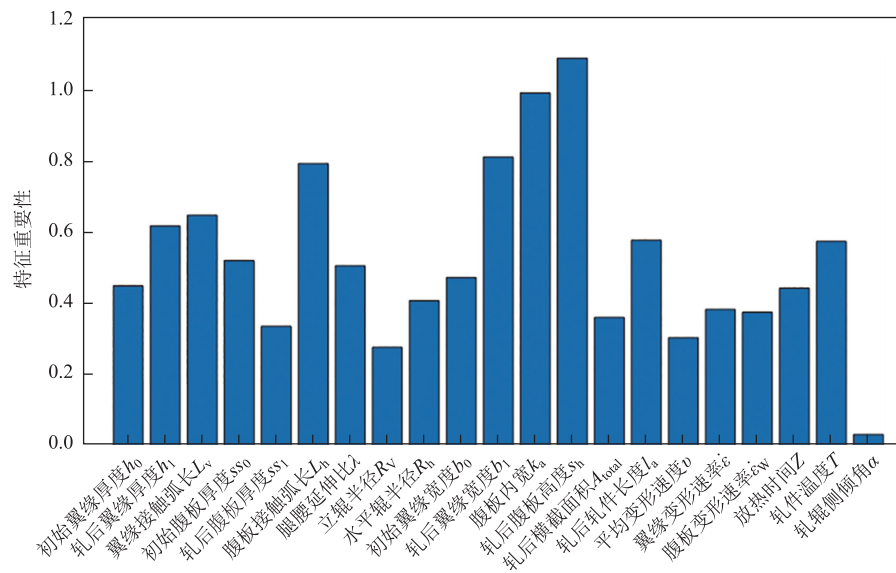


图 5 特征重要性分布图

Fig. 5 Distribution diagram of feature importance

$$D_1(a, s) = \{x \mid x^{(a)} \leq s\} \quad (12)$$

$$D_2(a, s) = \{x \mid x^{(a)} > s\} \quad (13)$$

$$c_1 = \text{ave}[y_i \mid x_i \in D_1(a, s)] \quad (14)$$

$$c_2 = \text{ave}[y_i \mid x_i \in D_2(a, s)] \quad (15)$$

式中： a 为变量属性； s 为对应的变量值； D_1 、 D_2 为两个样本集； c_1 、 c_2 分别为样本集 D_1 、 D_2 的输出 y_i 均值； x_i 为对应样本集中的特征值； y_i 为对应样本集中的目标值， $i=1, 2, 3, \dots$ 。

在随机森林回归模型的训练过程中，输入空间内的数据集被递归划分为多个子区域，以此构建一系列二叉决策树。每个子区域的输出值由相应的决策树确定。模型的最终预测值为这些决策树预测结果的平均值，这种方法允许模型通过集成多个简单

模型的预测来提高预测的准确性和稳定性。

$$H_r = \frac{1}{n} \sum_{l=1}^n h_{\text{Dl}} \quad (16)$$

式中： H_r 为随机森林模型的预测值； n 为决策树的总数； h_{Dl} 为第 l 棵决策树的预测值。

由于随机森林的这种结构设计使其在处理大规模数据集时具有高效的训练效率，并且由于模型中的随机性，它具备较强的抗干扰能力和优秀的泛化性能，因此，本文选择随机森林模型进行 H 型钢水平辊轧制力的预测。

随机森林算法结构图如图 6 所示，步骤如下。

(1) 随机采样：采用 Bootstrap 自助采样法，从原始数据集中有放回地抽取多个子样本集，为每棵

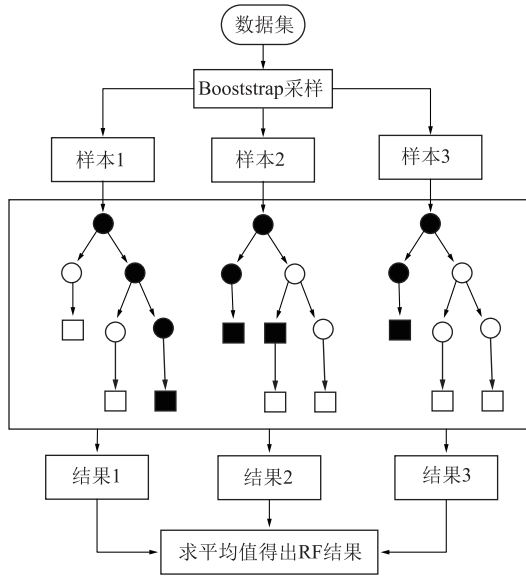


图 6 随机森林算法结构图

Fig. 6 Structure chart of random forest algorithm

决策树提供独立的训练数据。

(2) 随机特征选择：在构建每棵决策树的每个节点时，从一个随机确定的特征子集中选择最优特征进行节点分裂。

(3) 构建决策树：根据随机特征选择的结果，递归地构建决策树，直至达到预定的停止条件，如节点的最小样本数或树的最大深度。

(4) 模型集成：将构建的所有决策树集成起来，形成随机森林。每棵树均独立生长，不进行剪枝。

(5) 结果汇总：对于给定的输入，每棵树都会给出一个预测值，随机森林的最终预测结果是所有决策树预测值的平均值。

3.2 北方苍鹰优化算法

北方苍鹰优化算法 NGO 是由 Dehghani M 等^[21]于 2021 年提出的一种基于北方苍鹰觅食行为的优化算法。该算法通过模拟北方苍鹰的飞行策略、个体行为与群体协作、飞行速度和方向调整、随机扰动和局部搜索以及适应度评估等原理，使得该算法能够在解空间中搜索最优解或接近最优解的解决方案，具有一定的搜索能力和收敛性，适用于解决复杂优化问题。NGO 算法的主要原理如下。

(1) 飞行策略模拟：NGO 算法中的优化过程是基于北方苍鹰飞行策略的模拟。北方苍鹰是一种迁徙鸟类，它们在觅食过程中会展开广泛的搜索，并通过协作提高觅食效率。NGO 算法通过模拟北方苍鹰的飞行策略进行优化。

(2) 个体行为与群体协作：NGO 算法中，个体代表了一个解决方案，它们通过自身的行为、与其他个体的协作来搜索最优解。个体的行为包括飞行和觅食，而协作则是通过信息交流和位置调整来实现的。

(3) 飞行速度和方向调整：NGO 算法中，个体的飞行速度和方向根据当前位置和周围环境信息进行调整。个体会根据周围个体的位置和适应度值，调整自身的速度和方向，以更好地搜索解空间。

(4) 随机扰动和局部搜索：NGO 算法中，个体还具有随机扰动和局部搜索的行为。随机扰动是为了增加搜索的多样性，避免陷入局部最优解。局部搜索是指个体在一定范围内进行更加精细的搜索，以找到更优的解决方案。

(5) 适应度评估：在 NGO 算法中，每个个体的适应度是根据目标函数的值来评估的。适应度值越好，个体的位置越接近最优解。

NGO 算法的迭代过程分为猎物识别阶段（探索阶段）以及追逐和逃跑阶段（利用阶段）：

(1) 第 1 阶段（探索阶段）：北方苍鹰在捕猎的第 1 阶段，随机选择一个猎物，然后快速攻击。由于在搜索空间中猎物的选择是随机的，这一阶段增加了 NGO 的探索能力，将导致搜索空间的全局搜索，目的是确定最优区域，其数学模型为：

$$P_q = X_K, K = 1, 2, 3, \dots, q-1, q, q+1, \dots, N \quad (17)$$

$$x_{q,j}^{\text{new},P1} = \begin{cases} x_{q,j} + r(p_{q,j} - Ix_{q,j}), & F_{p_q} < F_q \\ x_{q,j} + r(x_{q,j} - p_{q,j}), & F_q < F_{p_q} \end{cases} \quad (18)$$

$$X_q = \begin{cases} X_q^{\text{new},P1}, & F_q^{\text{new},P1} < F_q \\ X_q, & F_q^{\text{new},P1} \geq F_q \end{cases} \quad (19)$$

式中： P_q 为第 q 个北方苍鹰猎物的位置； X_K 为第 K 个初始化位置； N 为自然数； $x_{q,j}^{\text{new},P1}$ 为探索阶段第 q 只北方苍鹰在 j 维选择的猎物最新位置； $x_{q,j}$ 为第 q 只北方苍鹰在 j 维中的位置； $p_{q,j}$ 为 P_q 的第 j 维分量；参数 r 和 I 均为随机数，用于在搜索和更新过程中产生随机 NGO 行为， $r \in [0, 1]$ ， $I = 1, 2$ ； F_{p_q} 、 F_q 分别为第 q 只北方苍鹰的目标函数值以及其选择猎物的目标函数值； $F_q^{\text{new},P1}$ 为探索阶段更新后第 q 只苍鹰的目标函数值； $X_q^{\text{new},P1}$ 、 X_q 分别为 $F_q^{\text{new},P1} < F_q$ 时和 $F_q^{\text{new},P1} \geq F_q$ 时探索阶段第 q 个苍鹰的更新位置^[22]。

(2) 第 2 阶段（利用阶段）：当北方苍鹰攻击猎物后，猎物试图逃跑，在猎物逃跑的过程中，北方苍鹰继续追逐猎物。由于北方苍鹰的高速度，它们几乎可以在任何情况下追逐猎物并最终捕获猎物。该算法对这种行为的模拟提高了算法对搜索空间局部搜索的能力，假设这次狩猎范围的半径为 R_1 ，两者之间追逐过程的数学表达式为：

$$x_{q,j}^{new,P2} = x_{q,j} + R_1(2r - 1)x_{q,j} \quad (20)$$

$$R_1 = 0.02(1 - \frac{t}{T'}) \quad (21)$$

$$X_q = \begin{cases} X_q^{new,P2}, & F_q^{new,P2} < F_q \\ X_q, & F_q^{new,P2} \geq F_q \end{cases} \quad (22)$$

式中： $X_q^{new,P2}$ 为利用阶段第 q 只苍鹰的最新位置； $x_{q,j}^{new,P2}$ 为 $X_q^{new,P2}$ 的第 j 维分量； t 为当前迭代次数； T' 为最大迭代次数； $F_q^{new,P2}$ 为利用阶段第 q 只苍鹰的目标函数值^[23]。

3.3 NGO-RF 模型流程

本文利用孤立森林进行离群点检测，利用树模型进行特征选择，利用北方苍鹰优化算法对随机森林的随机树以及最小叶子节点数进行寻优组合，并使用最优参数对数据进行预测，最优参数组合为随机森林随机树的数量，为 43 棵，每棵树的最小叶节点大小为 1。整体模型流程图如图 7 所示，具体步骤描述如下：

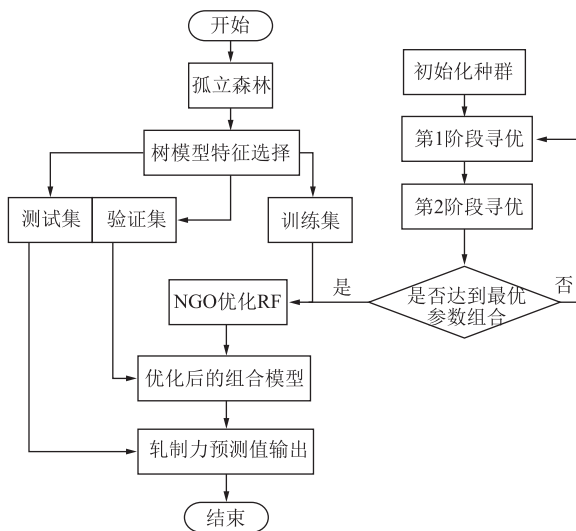


图 7 NGO-RF 模型流程图

Fig. 7 Flow chart of NGO-RF model

(1) 利用采集到的初始参数计算相关特征，并建立数据集；

(2) 利用孤立森林与树模型进行离群点检测和

特征选择；

(3) 读取数据集，划分训练集（80%）、验证集（10%）与测试集（10%），对数据归一化处理；

(4) NGO 与 RF 模型的初始化与参数设置，参数设置如表 1 所示；

(5) 利用 NGO 优化算法对 RF 进行参数寻优；

(6) 输出最优参数组合，并将测试集数据输入至 NGO-RF 模型，输出轧制力的预测值。

表 1 算法基本参数

Table 1 Basic parameters of algorithm

参数	数值
最大速度	[50, 2]
最小速度	[-10, -1]
最大边界	[200, 22]
最小边界	[50, 1]
优化参数下边界	[1, 1]
优化参数上边界	[5, 5]
种群数目	20
最大迭代次数	200

4 模型评价与结果分析

4.1 评价指标

本文采用拟合决定系数 R^2 、平均绝对误差 MAE 以及均方根误差 $RMSE$ 作为模型评价指标。在模型性能评价指标中，决定系数 R^2 衡量的是预测模型对目标数据的拟合程度，平均绝对误差 MAE 衡量的是预测值与实测值之间差异的平均大小，均方根误差 $RMSE$ 衡量的是预测值与实测值之间差异的平方和的平均值的平方根， R^2 值越接近 1 越好， MAE 与 $RMSE$ 越小越好。

4.2 预测模型结果分析

为验证本文所建模型的正确性与有效性，在相同的初始参数、迭代次数与种群数目的条件下将本文北方苍鹰优化随机森林（NGO-RF）模型与随机森林模型（RF）、支持向量机模型（SVM）、多层感知神经网络模型（MLP）、卷积神经网络模型（CNN）、北方苍鹰优化支持向量机模型（NGO-SVM）以及北方苍鹰优化多层感知神经网络模型（NGO-MLP）进行对比，本文模型能够较好地预测 H 型钢水平辊轧制力，评价指标均优于上述模型。各模型评价指标计算如表 2 所示，各模型测试集评价指标如图 8、图 9 所示，拟合散点图如图 10 所示。

表 2 各模型评价性能指标计算结果

Table 2 Calculation results of performance evaluation indexes for various models

预测模型	MAE			RMSE			R ²		
	训练集	验证集	测试集	训练集	验证集	测试集	训练集	验证集	测试集
RF	418.37	302.50	408.74	537.98	392.12	512.23	0.90570	0.93336	0.94213
SVM	635.33	405.40	679.32	805.27	481.35	861.29	0.78872	0.89959	0.83638
MLP	497.30	347.17	555.30	670.73	431.06	721.47	0.85342	0.91947	0.88519
CNN	621.58	419.65	677.57	783.41	512.49	791.45	0.80004	0.88617	0.86184
NGO-SVM	638.26	377.50	739.12	803.76	465.48	859.79	0.78951	0.90610	0.83695
NGO-MLP	453.47	257.41	503.97	582.01	348.85	609.95	0.88964	0.94726	0.91794
NGO-RF	246.61	183.60	294.72	325.35	303.04	404.24	0.96551	0.96020	0.96396

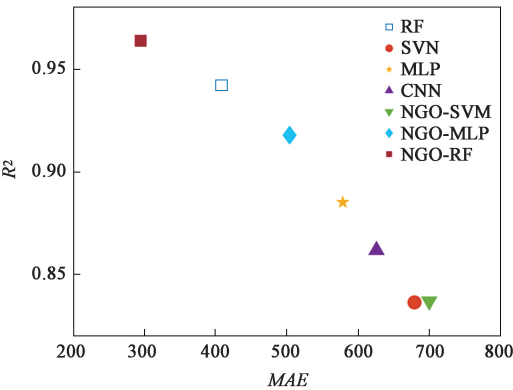


图 8 各模型 R² 与 MAE 对比

Fig. 8 Comparison of R² and MAE among various models

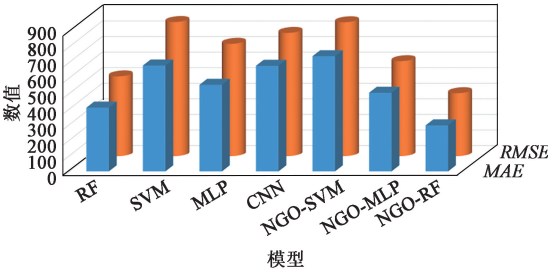


图 9 各模型 MAE 与 RMSE 对比

Fig. 9 Comparison of MAE and RMSE among various models

根据表 2 可以观察到，RF 模型相较于 SVM、MLP 和 CNN 这 3 种基本模型表现更优。具体而言，SVM 和 CNN 模型在训练集与测试集上的评价指标 (MAE 和 RMSE) 均较高，相对于其他模型而言，虽然 SVM 和 CNN 模型在验证集上性能略有提升，但是二者的预测精度仍然较差，不足以满足实际生产的需要。进一步对比这 4 种基本模型可以发现，RF 模型在测试集、验证集和训练集上的性能均优于其他三者，因此本文将作为基础模型。为了进一步提高轧制力预测的准确性，引入 NGO，分别对

SVM、MLP、CNN 和 RF 模型进行了优化。结果表明，NGO 的加入可以显著提高轧制力模型的预测精度。具体而言，经过优化后本文 NGO-RF 模型在测试集上的 MAE 降低了 114.02，RMSE 降低了 107.99，R² 提高了 2.3%。由于 NGO 优化后的 CNN 模型运行时间较长且精度不如本文 NGO-RF 模型，本文未将其与上述模型进行对比。综上所述，本文提出的 NGO-RF 模型在训练集、验证集和测试集上的性能均优于其他模型。由图 8 中可见，本文 NGO-RF 模型的 MAE 最小，R² 最大；由图 9 可见，NGO-RF 模型的柱状图均低于其他模型，也可以进一步说明本文 NGO-RF 模型优于其他模型；图 10 展示了各模型在测试集上的散点图，可以看到，RF、NGO-MLP 和本文 NGO-RF 模型的拟合程度较好，均匀分布于拟合直线两侧。综上所述，本文 NGO-RF 模型相较于其他模型具有最佳的预测性能与最高的预测精度。

图 11 展示了本文 NGO-RF 模型与其他 6 种模型的轧制力预测值与实测值对比结果。从图 11 中可以看出，尽管所有模型的预测趋势与实测值趋势相同，但轧制力实测值受设备震动、轧机配合精度、温度变化等多种因素的影响，导致在不同轧机操作条件下轧制力出现显著波动，也使得部分预测模型精度较差。具体来看：SVM 模型表现出较高的误差和不稳定性；相较于 SVM 模型，CNN 模型的预测准确度有所提升，但预测精度仍难以满足实际需要；与 CNN 和 SVM 模型相比，MLP 模型在预测精度和稳定性上均有所增强，但是与 RF 模型相比，其预测性能稍有不足。所以将 RF 模型作为本文的基础模型，可以更好地实现 H 型钢水平辊轧制力的预测；NGO-SVM 模型是在 SVM 模型的基础上优化得到的，虽然其提升效果不显著，但是相较于 SVM 模型仍

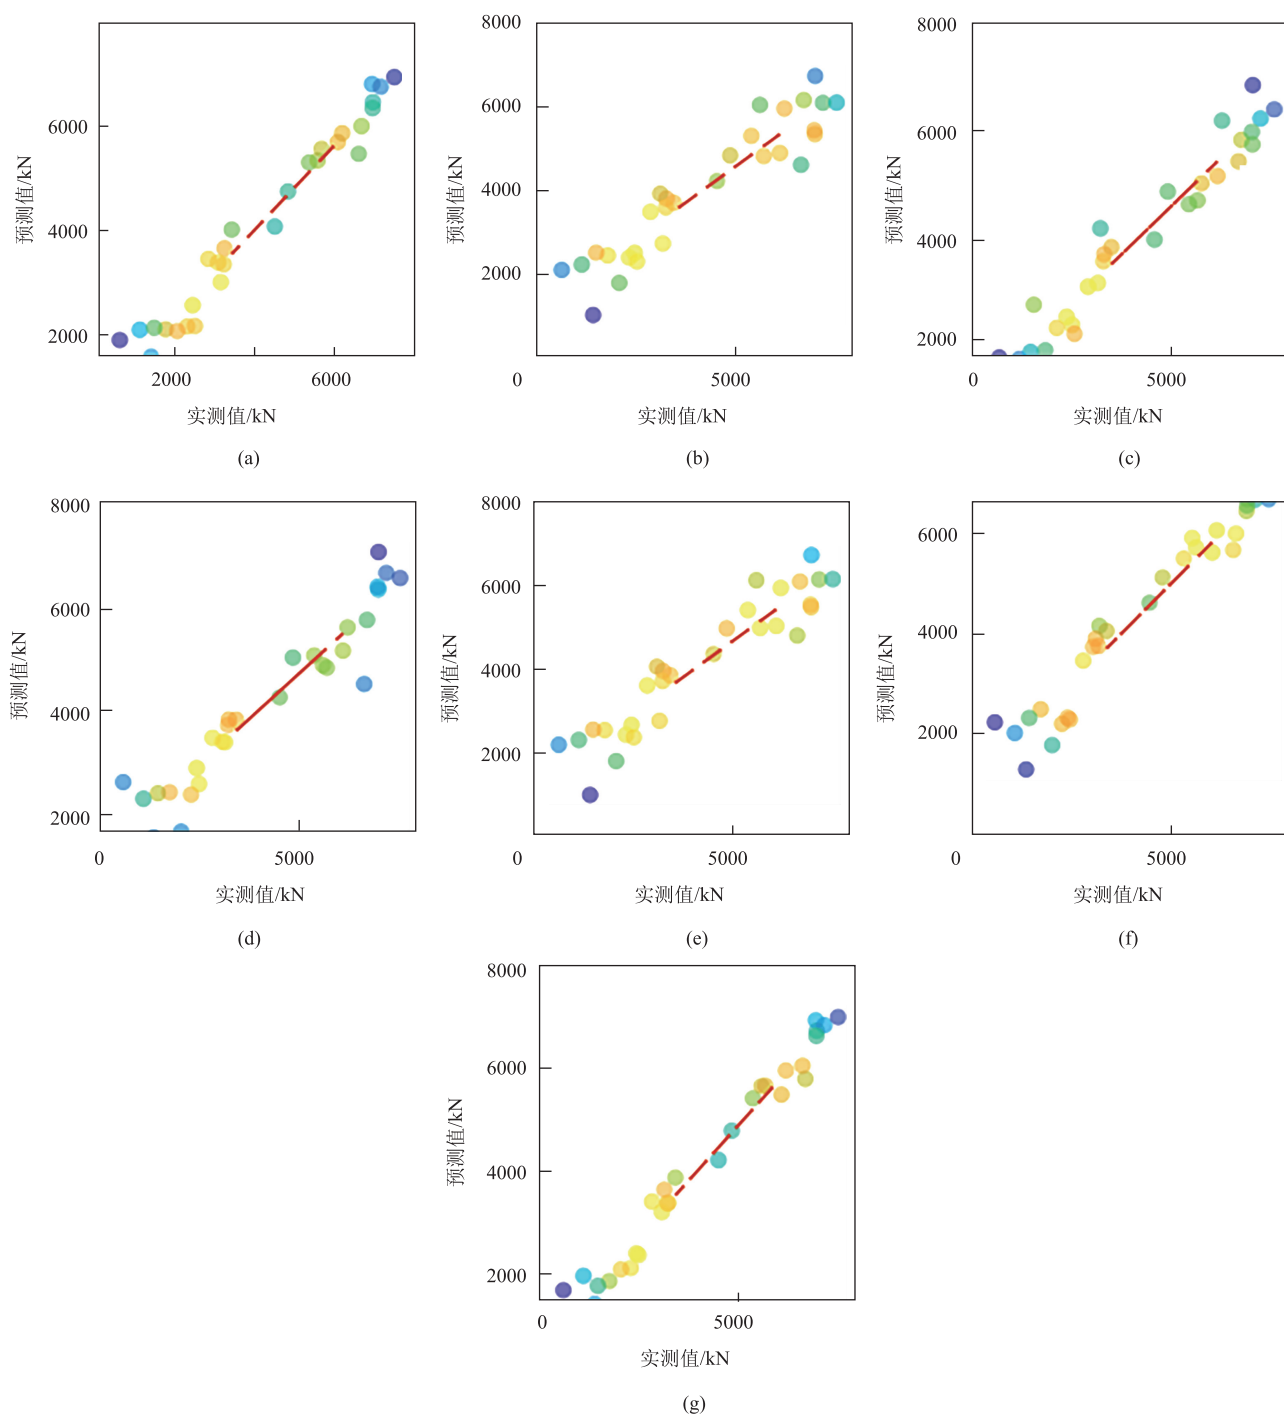


图 10 各模型测试集拟合散点图

(a) RF (b) SVM (c) MLP (d) CNN (e) NGO-SVM (f) NGO-MLP (g) NGO-RF

Fig. 10 Scatter plots of test set fitting for various models

有部分提升；相比单独的 MLP 模型，NGO-MLP 模型的预测准确度进一步提升，显示出 NGO 算法在提高模型准确度方面的效果；在所有对比模型中，本文 NGO-RF 模型始终保持较高的准确度和稳定性，特别是在轧制力波动较大的点上，具有更好的预测效果。

为了更好地证明本文 NGO-RF 模型的预测效果，选取 588 mm×300 mm×12 mm×20 mm（下文均称“588×300”）新规格产品进行轧制力实测值与模型预测值的对比，对比结果如图 12 所示，实测值、预测值与相对误差如表 3 所示。由图 12 可知，轧制力预测值与实测值相差不大，从表 3 可知，两者的平

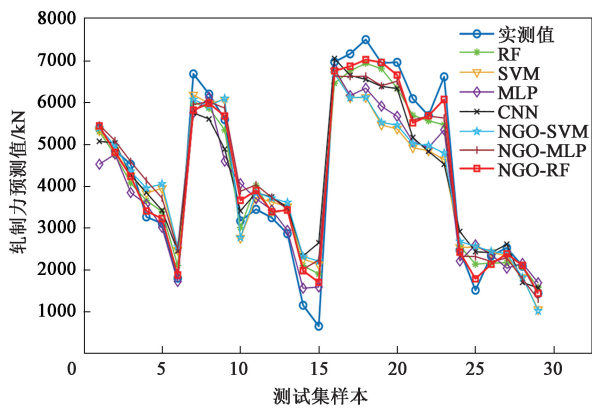


图 11 各模型预测结果与实测值对比图

Fig. 11 Comparison chart of predicted results and measured values for various models

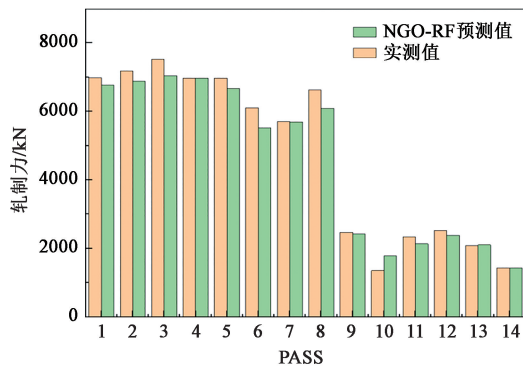


图 12 588×300 新规格产品的实测与预测轧制力对比

Fig. 12 Comparison of measured and predicted rolling forces for new product with specification of 588×300

均相对误差为 6.05%。由于厂内轧制以生产为主,未对 H 型钢轧制压下量合理分配,导致腿腰延伸比 λ 忽高忽低。而 λ 的大小对轧制力的影响非常大, λ 越大,水平辊轧制力越小。而针对这一新规格,由于实际生产中未合理地分配压下率,PASS 10 的腿腰延伸比很大,使得实际轧制力较小,造成误差较大的情况。虽然模型预测的轧制力值与实测值仍然存在一些误差,但是本文 NGO-RF 模型可以更有效地预测 H 型钢的水平辊轧制力,为实际生产提供理论指导。

5 结论

(1) 本文重点研究热轧 H 型钢水平辊轧制力的预测问题,采用随机森林模型作为基础预测模型,并引入北方苍鹰优化算法对模型参数寻优,建立了适用于多规格 H 型钢水平辊轧制力预测的 NGO-RF 模型,可以实现 H 型钢水平辊轧制力的有效预测。

表 3 轧制力实测值与预测值结果

Table 3 Results of measured and predicted values for rolling force

道次编号	PASS	实测值/kN	模型预测值/kN	相对误差/%
第 1 道次	1	6981.11	6767.40	3.06
	2	7175.87	6878.30	4.15
第 2 道次	3	7517.13	7035.80	6.40
	4	6958.93	6970.70	0.17
第 3 道次	5	6972.63	6668.80	4.36
	6	6099.85	5520.70	9.49
第 4 道次	7	5696.87	5693.00	0.07
	8	6625.81	6083.60	8.18
第 5 道次	9	2470.84	2420.40	2.04
	10	1357.78	1783.60	31.36
第 6 道次	11	2333.62	2132.20	8.63
	12	2527.97	2385.00	5.66
第 7 道次	13	2085.95	2104.80	0.90
	14	1432.33	1434.80	0.17

(2) 结合传统轧制力模型的理论公式,本研究构建了具有多个独立变量的输入特征数据集,并运用孤立森林算法和树模型进行离群点检测与特征选择。将初始 21 个特征降低至 13 个,有效地消除了无关变量的干扰,并降低了预测模型的复杂性,从而提升了模型的计算效率和预测精度。

(3) 与 RF、SVM、MLP、CNN、NGO-SVM、NGO-MLP 模型比较,本文 NGO-RF 模型具有更高的预测性能与最佳的综合性能。针对 588×300 新规格产品的预测,本文模型的预测值与实测值相差不大,充分证明了其在预测热轧 H 型钢水平辊轧制力方面的有效性。

参考文献:

- [1] 顾波,王娇,白晶. 基于热连轧机厚度精度的最优控制研究[J]. 机床与液压, 2018, 46 (8): 126-128.
Gu B, Wang J, Bai J. Optimal control of thickness accuracy of hot rolling mill [J]. Machine Tool & Hydraulic, 2018, 46 (8): 126-128.
- [2] Wang Z H, Zhang D H, Gong D Y, et al. A new data-driven roll force and roll torque model based on FEM and hybrid PSO-ELM for hot strip rolling [J]. ISIJ International, 2019, 59 (9): 1604-1613.
- [3] Liu X, Liu X H, Song M, et al. Theoretical analysis of minimum metal foil thickness achievable by asymmetric rolling with fixed identical roll diameters [J]. Transactions of Nonferrous Metals Society of China, 2016, 26 (2): 501-507.

- [4] 王春华, 吕雷. 改进型支持向量回归预测模型的轧机轧制力预测 [J]. 传感器与微系统, 2017, 36 (4): 65-67, 70.
Wang C H, Lyu L. Rolling force prediction of rolling mill based on improved support vector regression prediction model [J]. Transducer and Microsystem Technologies, 2017, 36 (4): 65-67, 70.
- [5] 贺庆强, 张勤河, 张海龙. 应用综合仿真模型构建 H 型钢轧制力公式 [J]. 重型机械, 2008 (1): 6-10.
He Q Q, Zhang Q H, Zhang H L. Development of rolling force formula for H-beam rolling process by an integrated model [J]. Heavy Machinery, 2008 (1): 6-10.
- [6] 张海龙, 张勤河, 贺庆强, 等. H 型钢连轧过程轧制力模型的研究 [J]. 钢铁, 2009, 44 (4): 46-49.
Zhang H L, Zhang Q H, He Q Q, et al. Study on continuous rolling force model for H-beam [J]. Iron and Steel, 2009, 44 (4): 46-49.
- [7] 赵景云, 臧勇, 逢晓男, 等. 基于流函数的 H 型钢轧制力能参数模型 [J]. 北京科技大学学报, 2013, 35 (1): 112-119.
Zhao J Y, Zang Y, Pang X N, et al. Rolling energetic parameter model of H-beams based on the flowfunction [J]. Journal of University of Science and Technology Beijing, 2013, 35 (1): 112-119.
- [8] 张向军, 陈志强, 朱凤泉, 等. 一种 H 型钢矩形坯热轧开坯的轧制力能校核计算方法 [P]. 中国: CN115544449A, 2022-12-30.
Zhang X J, Chen Z Q, Zhu F Q, et al. A method for checking and calculating the rolling force energy of a rectangular billet hot rolling process for H-beam steel [P]. China: CN115544449A, 2022-12-30.
- [9] Zhang X D, Yao L, Zhou Z X. Rolling force prediction algorithm based on Bayesian regularization neural network [A]. Proceedings of the 2nd International Conference on Electronics, Network and Computer Engineering (ICENCE 2016) [C]. Paris: Atlantis Press, 2016.
- [10] 窦博. 热连轧轧制力贝叶斯神经网络预测与模型优化 [J]. 金属制品, 2017, 43 (6): 42-48.
Dou B. Prediction of rolling force and model optimization with Bayes neural network [J]. Metal Products, 2017, 43 (6): 42-48.
- [11] Zheng G, Ge L H, Shi Y Q, et al. Dynamic rolling force prediction of reversible cold rolling mill based on BP neural network with improved PSO [A]. Proceedings of 2018 Chinese Automation Congress (CAC) [C]. Xi'an: IEEE, 2018.
- [12] 魏立新, 魏新宇, 孙浩, 等. 基于改进遗传算法优化 SVM 的轧制力预报 [A]. 第 37 届中国控制会议论文集 [C]. 新泽西州皮斯卡特维: IEEE, 2018.
Wei L X, Wei X Y, Sun H, et al. Rolling force prediction of SVM based on improved genetic algorithm [A]. Proceedings of the 37th Chinese Control Conference [C]. Piscataway NJ: IEEE, 2018.
- [13] 马威, 李维刚, 赵云涛, 等. 基于深度学习的热连轧轧制力预测 [J]. 钢铁研究学报, 2019, 31 (9): 805-815.
Ma W, Li W G, Zhao Y T, et al. Prediction of hot-rolled roll force based on deep learning [J]. Journal of Iron and Steel Research, 2019, 31 (9): 805-815.
- [14] Wang W Y, Hua H, Zhang B S. Prediction model of rolling force based on KNN [J]. International Core Journal of Engineering, 2020, 6 (9): 158-162.
- [15] 冀秀梅, 王龙, 高克伟, 等. 极限学习机在中厚板轧制力预报中的应用 [J]. 钢铁研究学报, 2020, 32 (5): 393-399.
Ji X M, Wang L, Gao K W, et al. Application of ELM to predict plate rolling force [J]. Journal of Iron and Steel Research, 2020, 32 (5): 393-399.
- [16] 章顺虎, 姜兴睿, 尤凤翔, 等. 融合工业大数据的热轧厚板轧制力模型研究 [J]. 精密成形工程, 2020, 12 (2): 8-14.
Zhang S H, Jiang X R, You F X, et al. Investigation on the model of rolling force by integrating industrial big data [J]. Journal of Netshape Forming Engineering, 2020, 12 (2): 8-14.
- [17] 丁敬国, 刘方路, 于琨, 等. 基于 WOA-ELM-LSTM 的非稳态热轧过程轧制力预测 [J]. 钢铁研究学报, 2024, 36 (1): 85-94.
Ding J G, Liu F L, Yu K, et al. Prediction of hot rolling force based on WOA-ELM-LSTM in unsteady process [J]. Journal of Iron and Steel Research, 2024, 36 (1): 85-94.
- [18] 李加军. 基于孤立森林的多离群点数据检测算法设计 [J]. 现代电子技术, 2024, 47 (5): 139-142.
Li J J. Design of multi-outlier data detection algorithm based on isolation forest [J]. Modern Electronics Technique, 2024, 47 (5): 139-142.
- [19] 钱旭盛, 朱萌, 翟千惠, 等. 基于改进孤立森林算法的异常用电行为识别方法 [J]. 沈阳工业大学学报, 2023, 45 (6): 601-606.
Qian X S, Zhu M, Zhai Q H, et al. Abnormal electrical behavior recognition method based on improved isolated forest algorithm [J]. Journal of Shenyang University of Technology, 2023, 45 (6): 601-606.
- [20] Breiman L. Random forests [J]. Machine Learning, 2001, 45: 5-32.
- [21] Dehghani M, Hubálovský Š, Trojovský P. Northern goshawk optimization: A new swarm-based algorithm for solving optimization problems [J]. IEEE Access, 2021, 9: 162059-162080.
- [22] 陈萱, 杨永超, 袁博洋, 等. NGO-VMD 和 SSNGO-RF 算法在风机齿轮箱故障诊断中的应用 [J]. 湖北民族大学学报 (自然科学版), 2023, 41 (4): 520-529.
Chen X, Yang Y C, Yuan B Y, et al. Application of NGO-VMD and SSNGO-RF algorithms in fault diagnosis of wind turbine gearboxes [J]. Journal of Hubei Minzu University (Natural Science Edition), 2023, 41 (4): 520-529.
- [23] 包金山, 杨定坤, 张靖, 等. 基于特征提取与 INGO-SVM 的变压器故障诊断方法 [J]. 电力系统保护与控制, 2024, 52 (7): 24-32.
Bao J S, Yang D K, Zhang J, et al. Transformer fault diagnosis method based on feature extraction and INGO-SVM [J]. Power System Protection and Control, 2024, 52 (7): 24-32.